

SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET
Diplomski studij naftnog rudarstva

**USKLADIVANJE SIMULACIJSKOG MODELA
JEZGRE STIJENE I LABORATORIJSKOG TESTA
NEUSTALJENOG PROTOKA**

Diplomski rad

Filip Kos

N 187

Zagreb, 2017.

USKLAĐIVANJE SIMULACIJSKOG MODELA JEZGRE STIJENE I LABORATORIJSKOG TESTA
NEUSTALJENOG PROTOKA

FILIP KOS

Rad je izrađen na: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za naftno inženjerstvo
Pierottijeva 6, 10 000 Zagreb

Sažetak

Izrađen je simulacijski model jezgre stijene za numeričku simulaciju laboratorijskog eksperimenta specijalnih analiza jezgri stijena istiskivanja nafte s vodom. Model je izrađen kako bi se povezali podatci o relativnoj propusnosti i kapilarnom tlaku između laboratorijski kontroliranog protočnog uvjeta i simulacijskog modela. Eksperimentalni podatci interpretirani su analitičkim proračunom kako bi se utvrdilo podatke o relativnim propusnostima za naftu i vodu u odnosu na zasićenje fluidom. Simulacijski model jezgre stijene inicijaliziran je u skladu sa dimenzijama i geometrijom laboratorijskog uzorka, osnovnim svojstava stijena i fluida, te karakteristikama eksperimenta i eksperimentalnih rezultata. Testirane su različite postavke simulacijske mreže (dimenzije i broj ćelija) između kojih je ispitan simulacijski model kojemu su dimenzije ćelija od 1,5 do 2,5 mm i sastoji se od preko 15 tisuća ćelija. Modeliranjem laboratorijskog eksperimenta usklađeni su proizvodni rezultati prilagođavanjem krivulje relativnih propusnosti za naftu i vodu prema Corey-Brooks korelaciji. Svaka postavka simulacijske mreže ćelija zahtijevala je različite krivulje relativnih propusnosti da bi se uskladili rezultati. Krivulje relativnih propusnosti testirane simulacijskim modelom jezgre imaju veću pouzdanost za predviđanje procesa proizvodnje simulacijom na razini ležišta. Model služi za interpretaciju sirovih podataka iz laboratorijskih testova višefaznog protoka i kapilarnog tlaka, uz reproducibilnost mjerenih podataka simulacijom.

Ključne riječi: simulacijski model, specijalne analize jezgri stijena, numerička simulacija

Diplomski rad sadrži: 56 stranica, 8 tablica, 25 slika i 7 referenci.

Jezik izvornika: Hrvatski

Pohrana rada: Knjižnica Rudarsko-geološko-naftnog fakulteta, Pierottijeva 6, Zagreb

Mentor: Izv. prof. dr. sc. Domagoj Vulin

Ocjenjivači: Izv. prof. dr. sc. Domagoj Vulin
Izv. prof. dr. sc. Tomislav Kurevija
Doc. dr. sc. Luka Perković

3D CORE-FLOOD SIMULATION MODEL FOR UNSTEADY STATE RELATIVE PERMEABILITY
DATA TUNING

FILIP KOS

Thesis completed at: University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering
Petroleum Engineering Department
Pierottijeva 6, 10 000 Zagreb

Abstract

A 3D core sample model for numerical simulation of unsteady state water-flood test performed in lab has been made. The water-oil fluid displacement model is developed and initialized with a purpose to show how the laboratory obtained relative permeability and capillary pressure data can be linked to a numerical model that can provide the same results as an actual physical system. Relative permeability data can then be tuned for a better match with lab data and therefore it can be representative for further reservoir modeling. Experimental laboratory was first analytically interpreted to determine the relative permeability versus saturation data for oil and water, following the initialization of the core model in accordance with the laboratory sample dimensions and geometry, physical and fluid properties, experimental characteristics and results. The model is history matched with production rates reported from laboratory, i.e. by adjusting the laboratory obtained relative permeability curves in accordance with Corey-Brooks correlation. Core-flood simulation results are compared to experimental results and shown in a chronological way according to 4 different types of tested grid blocks versus relative permeability data. Experimental data is successfully and accurately matched with every model, all of which required slightly different water and oil relative permeability curves in relation to one another. The results confirmed the thesis, demonstrated the sensitivity of the precise micromodel (one of which consists out of over 15 thousand grid block cells) and showed how it can be a valuable tool for observing important physics including heterogeneity on a small precise scale that could be translated on to a larger scale dimensions, that of a reservoir.

Keywords: simulation model, special core analysis, numerical simulation

Thesis contains: 56 pages, 8 tables, 25 figures and 7 references.

Original in: Croatian

Archived in: Library of Faculty of Mining, Geology and Petroleum Engineering, Pierottijeva 6, Zagreb

Supervisor: Associate Professor Domagoj Vulin, PhD

Reviewers: Associate Professor Domagoj Vulin, PhD
Associate Professor Tomislav Kurevija, PhD
Assistant Professor Luka Perković, PhD

SADRŽAJ

POPIS TABLICA	II
POPIS SLIKA	III
POPIS KORIŠTENIH OZNAKA I ODGOVARAJUĆIH SI JEDINICA	V
1. UVOD.....	1
2. PRINCIPI INICIJALIZACIJE SIMULACIJSKOG MODELA	4
2.1. Simulacija ležišta ugljikovodika	4
2.2. Laboratorijske specijalne analize jezgri stijena - relativna propusnost i kapilarni tlak.....	6
2.3. Metode diskretizacije prostora - uspostavljanje kružne geometrije mreže ćelija ...	9
2.4. Struktura simulacijskog modela - organizacija ulaznih podataka.....	13
2.5. Korelacija krivulje relativnih propusnosti za simulacijski model	14
3. INTERPRETACIJA ULAZNIH PODATAKA LABORATORIJSKOG EKSPERIMENTA - ANALITIČKI PRORAČUN	16
4. SIMULACIJSKI MODEL SPECIJALNIH ANALIZA JEZGRE STIJENE - MODELIRANJE I REZULTATI.....	22
4.1. Model broj 1 (5x25x25 LAB).....	22
4.2. Model broj 2 (5x25x25).....	26
4.3. Model broj 3 (25x25x25).....	31
4.4. Model broj 4 (1D).....	38
5. ZAKLJUČAK.....	45
6. LITERATURA	46

POPIS TABLICA

Tablica 3-1 Set podataka o svojstvima stijena i fluida, karakteristikama uzorka i eksperimenta.....	16
Tablica 3-2 Set podataka mjerenih laboratorijskih vrijednosti dvofaznog protoka laboratorijskog ulja i vode	18
Tablica 3-3 Analitički proračunat set podataka o relativnim propusnostima u odnosu na zasićenje fluidima	21
Tablica 4-1 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 1 (5x25x25 LAB) od laboratorijskog eksperimenta.....	25
Tablica 4-2 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 2 (5x25x25) od laboratorijskog eksperimenta.....	29
Tablica 4-3 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 3 (25x25x25 LAB) od laboratorijskog eksperimenta.....	34
Tablica 4-4 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 3 (25x25x25 Corey-Brooks) od laboratorijskog eksperimenta.....	36
Tablica 4-5 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 4 (1D) od laboratorijskog eksperimenta.....	40

POPIS SLIKA

Slika 2-1 Uzorak jezgre stijene promjera 3,81 cm.....	6
Slika 2-2 Velika jezgra uzeta u ispitivanom intervalu bušotine	7
Slika 2-3 Aparatura za mjerenje relativne propusnosti, prikaz prednje i stražnje strane	8
Slika 2-4 Element koji prijanja na bazu valjka uzorka stijene, na izlaznom poklopcu držača8	
Slika 2-5 Primjeri primjene metode konačnih elemenata za aproksimaciju kruga (Reddy, 1984); preuređeno od Kos (2017).....	11
Slika 4-1 Krivulje relativnih propusnosti utvrđene laboratorijskom analizom.....	22
Slika 4-2 3D prikaz geometrije modela broj 1 (5x25x25 LAB) (t=1 min)	23
Slika 4-3 3D prikaz testirane geometrije (5x51x51) za model broj 1	23
Slika 4-4 Usporedni prikaz proizvodnje nafte prvog modela (5x25x25 LAB) i laboratorijski mjerenih vrijednosti.....	24
Slika 4-5 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (5x25x25 LAB)	26
Slika 4-6 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela broj 2 (5x25x25)	28
Slika 4-7 Krivulje relativnih propusnosti prilagođene prema Corey-Brooks korelaciji za model broj 2 (5x25x25).....	30
Slika 4-8 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (5x25x25)	30
Slika 4-9 Trodimenzionalni prikaz geometrije modela broj 3 (25x25x25) (t=2,22 min)....	32
Slika 4-10 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela 3 (25x25x25) inicijaliziranog laboratorijskim krivuljama.....	33
Slika 4-11 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela 3 (25x25x25) inicijaliziranog krivuljama korelacije	35
Slika 4-12 Krivulje relativnih propusnosti prilagođene prema Corey-Brooks korelaciji za model broj 3 (25x25x25).....	37
Slika 4-13 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (25x25x25 Corey-Brooks)	37
Slika 4-14 Trodimenzionalni prikaz geometrije modela broj 4 (50x1x1) (t=1 min).....	38
Slika 4-15 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela 4 (50x1x1)	39

Slika 4-16 Krivulje relativnih propusnosti prilagođene prema Corey-Brooks korelaciji za model broj 4 (1D)	41
Slika 4-17 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (1D)	41
Slika 4-18 Međusobno usporedni prikaz proizvodnih krivulja laboratorijske analize i svih testiranih modela	42
Slika 4-19 Usporedan prikaz krivulja relativnih propusnosti prema Corey-Brooks korelaciji korištenih za usklađivanje rezultata modelima 2, 3 i 4	43
Slika 4-20 Krivulja kapilarnog tlaka korištena tijekom ispitivanja.....	43

POPIS KORIŠTENIH OZNAKA I ODGOVARAJUĆIH SI JEDINICA

Oznaka	Jedinica	Opis
a	cm	duljina stranice elementa
A	cm^2	površina poprečnog presjeka jezgre stijene
A_{dsc}	cm^2	površina diskretizirane domene
A_e	cm^2	površina elementa
A_n	cm^2	površina n broja elemenata
A_o	cm^2	površina kruga jezgre
D	cm	promjer jezgre
f_w	-	frakcijski protok vode
k	cm^2	apsolutna propusnost stijene
k_h	cm^2	horizontalna propusnost
$k_o @ S_{wi}$	cm^2	propusnost za naftu pri S_{wi}
k_{o-eff}	cm^2	efektivna propusnost nafte
$k_r(n)$	-	relativna propusnost pri točki n zasićenja fluidom
$k_{r max}$	-	maksimalna vrijednost relativne propusnosti
$k_{r norm(S=n)}$	-	normalizirana vrijednost relativne propusnosti za n točku zasićenja fluidom
k_{rg}	-	relativna propusnost plina
$k_{rg, max}$	-	maksimalna vrijednost relativne propusnosti plina
k_{ro}	-	relativna propusnost nafte
$k_{ro, max}$	-	maksimalna vrijednost relativne propusnosti nafte
k_{rw}	-	relativna propusnost vode
$k_{rw, max}$	-	maksimalna vrijednost relativne propusnosti vode
k_v	cm^2	vertikalna propusnost
$k_w @ S_{or}$	cm^2	propusnost za vodu pri S_{or}
k_{w-eff}	cm^2	efektivna propusnost vode
L	cm	duljina jezgre stijene
n	-	konačni broj elemenata
n_g	-	eksponent za plin
n_o	-	eksponent za naftu
n_w	-	eksponent za vodu
OB	bar	simulirani tlak naslaga

$P.V.$	cm^3	porni volumen stijene
P_c	bar_a	kapilarni tlak
q_o	cm^3/s	volumetrijski protok nafte
q_w	cm^3/s	volumetrijski protok vode
r	cm	radijus jezgre
S	g/l	salinitet (NaCl) vode
S_g	-	zasićenje plinom
S_{gc}	-	konatno zasićenje plinom
S_o	-	zasićenje naftom
S_{oi}	-	inicijalno zasićenje naftom
S_{or}	-	rezidualno zasićenje naftom
S_w	-	zasićenje vodom
S_{wc}	-	konatno, intersticijalno, inicijalno zasićenje vodom
S_{wi}	-	inicijalno zasićenje vodom
t	h	vrijeme
t	min	vrijeme
T_o	$^{\circ}C$	temperatura nafte
T_w	$^{\circ}C$	temperatura vode
V	cm^3	volumen jezgre
V_{kor}	cm^3	korekcijski volumen zbog stlačivosti
V_o	cm^3	volumen nafte
V_{o+w}	cm^3	volumen nafte i vode
$V_{oi-p.v.}$	cm^3	inicijalni porni volumen nafte
$V_{o-p.v.}$	cm^3	porni volumen nafte
V_w	cm^3	volumen vode
$V_{wi-p.v.}$	cm^3	inicijalni porni volumen vode
x	cm	vrijednost granične koordinate kružnice na x -osi
y	cm	vrijednost granične koordinate kružnice na y -osi
Δp	Pa	razlika tlakova na ulazu i izlazu iz jezgre
μ_o	Pas	viskoznost nafte
μ_w	Pas	viskoznost vode
ρ_o	g/cm^3	gustoća nafte
ρ_w	g/cm^3	gustoća vode
Φ	-	poroznost

1. UVOD

U ovom diplomskom radu pristupilo se izradi simulacijskog modela jezgre stijene kojime se numerički simuliralo laboratorijski eksperiment specijalnih analiza jezgri stijena (engl. *Special Core Analysis, SCAL*) istiskivanja nafte sa vodom. U tu svrhu, izrađeno je i testirano nekoliko modela različitih karakteristika kojima bi se usporedno dobio najbolji rezultat. Modeliranje je izrađeno u simulatoru ECLIPSE kompanije Schlumberger.

Dostupni eksperimentalni podatci o relativnoj propusnosti i kapilarnom tlaku predstavljaju sustav na razini jezgre (engl. *core scale*). To su najčešće najpreciznije određeni podatci o višefaznom protoku za neko ležište. Inicijalizacijom simulacijskog modela jezgre stijene kojim bi se uskladilo protok fluida sa laboratorijskim testom (engl. *history matching*), što se postiže prilagođavanjem krivulje relativne propusnosti i kapilarnog tlaka, utvrdilo bi se reprezentativnu krivulju za isti protok, na dimenzijama jezgre u simulacijskoj aproksimaciji. Takva reprezentativna krivulja, ukoliko se pokazala kao dobra za simulacijski model jezgre (engl. *coreflood model*) ima veću pouzdanost za predviđanje procesa proizvodnje simulacijom na razini ležišta. Time se povezuje podatke koji proizlaze iz analiza na pornoj razini (engl. *pore scale*), koje nisu dostupne osim ukoliko se protok skenira CT uređajem, zatim podatke iz laboratorijskog testa zavodnjavanja koji su prvotno interpretirani analitički, te na kraju podatke koji se često aproksimiraju, a neophodni su za simulacijski model ležišta, kako bi se zbirno povezalo podatke mjerene u laboratoriju i proizvodne podatke o ležištu. Analitičkim proračunima zapravo se interpretiraju „zakašnjele“ informacije koje se odvijaju na pornoj razini, jer se uzorak (jezgra) interpretira kao tzv. blok-model za koji se računa materijalni balans. Time su podatci o pokretljivosti utiskivanog fluida u početku eksperimenta nepoznati, pošto na drugom kraju jezgre izlazi samo jedna faza (ona kojom je bila zasićena jezgra), na utisnom dijelu jezgre se nakuplja veće zasićenje utiskivanim fluidom te je nemoguće (bez CT skena) odrediti na pornoj razini zasićenja i posljedično relativnu propusnost za utiskivani fluid u pojedinom segmentu uzorka. Očito je da glede tog problema numerički modeli imaju stanovitu prednost u interpretaciji. U radu su ispitane različite postavke simulacijske mreže (dimenzije i broj ćelija). Ispitan je simulacijski model jezgre stijene kojemu su dimenzije ćelija od 1,5 do 2,5 mm i sastoji se od preko 15 tisuća ćelija, što predstavlja precizan opis stvarnog sustava. Takav model može imati više primjena, a primarno se

razvija sa svrhom da predstavlja bolji temelj za precizniju dinamičku simulaciju kompleksnijih procesa od primarnih metoda iskorištavanja ležišta ugljikovodika (EOR, skladištenje CO₂).

Shodno tome, postavlja se izazov konkretnog opisa takvog sustava uz pomagala koja imaju ograničene sposobnosti. Naime, dinamički simulacijski ležišni modeli sastoje od sustava ćelija koje svojim dimenzijama predstavljaju "grublju" reprezentaciju stvarnog prostora. Izazov se postavlja pri odabiru krivulje relativne propusnosti koja će najrealnije opisivati protok fluida u stvarnom sustavu koji je heterogen. Problem je u industriji što se u praksi često po tom pitanju samo podešavaju parametri u korelacijama za relativnu propusnost i izrađuje se osrednjavanjem jedinstvena krivulja za cijelo ležište, čime se zanemaruje stvarno mjerenje u laboratoriju koje predstavlja fizikalno opravdani rezultat (krivulju) i također se često zanemaruju vrijednosti kapilarnog tlaka. Naime, idealan pristup bio bi ne koristeći korelaciju, odabrati reprezentativnu krivulju relativne propusnosti i kapilarnog tlaka iz laboratorija koja je bila testirana simulacijom jezgre stijene. S obzirom na to da numerički modeli ležišta mogu uzimati u obzir heterogenost svojstava, teoretski najbolje rezultate bi se moglo dobiti razmatranjem većeg broja krivulja relativnih propusnosti utvrđenih na jezgrama iz različitih segmenata ležišta koje bi se tada modelom na takav način moglo opisati koristeći testirane realistične vrijednosti. No treba uzeti u obzir prihvatljivu granicu ekonomske isplativosti s obzirom na to da su procesi jezgrovanja i laboratorijskih analiza dugotrajni i skupi.

U ovom procesu simulacijski model jezgre stijene može biti koristan ležišnim inženjerima kao "posrednik" na kojemu se mogu uočavati važne zakonitosti protoka fluida na malim dimenzijama i preciznim rezolucijama, nakon čega bi se tako utvrđene ulazne podatke u simulacijskoj aproksimaciji (a povezane sa stvarnim fizikalnim mjerenjem) moglo postupno prevoditi na segmente većih dimenzija stijena (engl. *upscaling*) odnosno na dimenzije ležišta te postaviti kvalitetniji ležišni model.

Ovaj pristup „smanjenja rezolucije“ modela, zbog manje pouzdanosti podataka između bušotina i zbog ograničene računalne snage (tj. engl. *runtimea*), naziva se homogenizacijom.

Primjena simulacijskog modela jezgre stijene bila bi praktična u laboratoriju, gdje bi se u tako postavljenom modelu moglo povezivati i uspoređivati rezultate ispitivanja na

različitim uzorcima jezgri stijena te osigurati kvalitativne izlazne podatke, s obzirom na to da usklađivanje podataka o relativnoj propusnosti i kapilarnom tlaku nije baš jednoznačno niti za to postoji jasno definiran postupak. Simulacijski mikro-model ujedno bi bio i koristan za provjeru izvođenih mjerenja u laboratoriju čime bi se matematički simulacijski moglo potvrditi rezultate mjerenja.

Proces inicijalizacije simulacijskog modela jezgre stijene sastojat će se od nekoliko koraka, pri čemu će se prvobitno pristupiti uspostavljanju reprezentativne geometrije sustava pravokutnih ćelija (engl. *gridblock system*, ili *grid*) domene valjkastog oblika jezgre stijene, koristeći metodu diskretizacije konačnih elemenata, kako bi se omogućilo simulaciju kompleksnijih tlačnih raspodjela i raspodjela zasićenja, te analizu stohastičko definirane heterogenosti propusnosti. Pri tome, svaka će ćelija imati svoju koordinatu, a rubne vrijednosti površine poprečnog kružnog presjeka bit će određene algebarskom zakonitosti jednadžbe kružnice. Zatim će se analitičkim proračunom interpretirati podatci laboratorijskog eksperimenta kako bi se utvrdilo podatke o relativnim propusnostima za naftu i vodu u odnosu na zasićenje fluidom. Sljedeće, inicijalizirat će se simulacijski model jezgre stijene u skladu sa dimenzijama laboratorijskog uzorka, osnovnim svojstava stijena i fluida, te karakteristikama eksperimenta i eksperimentalnih rezultata. Inicijaliziranim modelom pristupit će se modeliranju laboratorijskog eksperimenta i usklađivanju proizvodnih rezultata (engl. *history matching*), testiranjem različitih sustava aproksimacijskih ćelija i metoda prilagođavanja laboratorijske krivulje relativne propusnosti. Konačno, prikazat će se usporedni rezultati modeliranja i laboratorijskih vrijednosti, uključujući trodimenzionalne prikaze svakog modela (geometrija, raspodjela zasićenja) i ostale parametre usporedbe.

Hipoteza rada glasi: numeričkim simulacijskim modelom jezgre stijene moguće je povezati podatke o relativnoj propusnosti i kapilarnom tlaku između laboratorijski kontroliranog protočnog uvjeta i simulacijskog modela i to tolikom preciznošću da se u laboratoriju mjereni proizvedeni volumeni fluida mogu simulacijski reproducirati u istim uvjetima bolje nego što je to izvedivo računski analitički.

Motivacija rada je time samoobjašnjiva – izrada ovakvog modela olakšat će interpretaciju sirovih podataka iz laboratorijskih testova višefaznog protoka i kapilarnog tlaka, uz jasnu potvrdu, tj. reproducibilnost mjerenih podataka simulacijom.

2. PRINCIPI INICIJALIZACIJE SIMULACIJSKOG MODELA

2.1. Simulacija ležišta ugljikovodika

Simulaciji ležišta ugljikovodika pristupa se kako bi se simuliralo buduću proizvodnju iz ležišta. Simulacijski je moguće testirati različite scenarije proizvodnje kako bi se pronašao optimalan pristup prije nego što se samo ležište u stvarnosti privede proizvodnji. Dok je vremensko-prostorni opis ležišta moguć u jednostavnim slučajevima primarnog pridobivanja ili kod proizvodnje plina, za plinsko-kondenzatna ležišta te doslovno sve tercijarne metode, koje uključuju brže fazne promjene, numerička simulacija je jedini način predviđanja buduće proizvodnje. Sami porini sustav ležišne stijene i protoka fluida kroz njega toliko je detaljan i odvija se na tako preciznoj razini da ga je nemoguće potpuno deterministički opisati ili simulirati bez velikog broja aproksimacija, interpolacija itd.

Problemi s kojima se susreće pri samoj inicijalizaciji simulacijskih modela ležišta uključuju (Pettersen, 2006):

- generalizaciju ulaznih podataka za opis stvarnog sustava na mikro skali, koji su dobiveni obzervacijama na makro skali (seizmički podatci, podatci iz bušotinske karotaže)
- postupno prevođenje podataka s preciznih rezolucija na veće dimenzije (engl. *upscaling*)
- određene nesigurnosti u samom programskom jeziku simulatora s obzirom na jednadžbe za višefazni protok fluida u poroznom mediju

S obzirom na takve nesigurnosti u vezi ulaznih podataka, ali i procedura rješenja, nije ni iznenađujuće da se ne mogu dobiti egzaktni odgovori, što se tipično i manifestira uspoređujući simulirane podatke sa stvarnim podacima nakon nekog vremena proizvodnje iz ležišta.

Razmatrani koncepti osobito su važni kada se radi o odobalnim postrojenjima za istraživanje i proizvodnju ugljikovodika na moru koje zahtijeva mnogo robustniju izvedbu radova i ekonomskog planiranja u odnosu na kopnena postrojenja. Naime, s obzirom na to

da su investicije unaprijed toliko velike u slučaju "offshore" operacija, potrebno je minimizirati pogreške u planiranju buduće proizvodnje.

Ležišni inženjeri koji se bave simulacijom ležišta fluida u tom kontekstu zaduženi su za (Pettersen, 2006):

- procjenu kvalitete ulaznih podataka
- transformaciju ulaznih podataka u formu koja je prigodna za simulaciju
- identifikaciju podataka koji su nepouzdana
- prepoznavanje potrebe za prikupljanjem dodatnih podataka
- identifikaciju ključnih podataka koji bi mogli izravno utjecati na izbor planiranih operacija, te nesigurnosti vezane za takve podatke
- postavljanje seta simulacijskih ležišnih modela za analizu
- procjenu kvalitete simuliranih podataka (rezultata), nesigurnosti, područja robusnosti
- iskoristiti stvarne dostupne podatke sa terena o proizvodnji kako bi se efektivno simulacijski modeli prema njima kalibrirali (podesili)
- ukazivanje na potencijalne buduće probleme, rješenja, predlaganje planova za proizvodnju

Prema navedenim odgovornostima može se vidjeti kako je simulator sam po sebi samo alat, koji je od neophodne važnosti, ali ljudski faktor, tj. osoba koja ga koristi od najveće je važnosti u samom procesu. Dok postavljanje simulacijskog modela u komercijalnom softveru poput Eclipsea predstavlja samo informatičku vještinu, izvrsno poznavanje fizikalnih procesa koji mogu u kompleksnom numeričkom sustavu proračuna napraviti veliku razliku ključan je element za simulaciju i analizu različitih simulacijskih slučajeva. Npr. komercijalni softveri dopuštaju definiciju nelogičnih odnosa parametara u prostoru (tlakovi, zasićenja fluidima itd.), međutim iste parametre je često moguće postaviti simulacijski, dobrom definicijom fizikalnih odnosa u simulacijskom modelu. Upravo taj dio – inicijalizacija modela pokazuje na koliko čvrstom temelju „stoji“ model. Tako npr. vezano uz spomenute parametre zasićenja, dobrim podešavanjem kontakta faza (kontakt nafta-voda, kontakt nafta-plin) i dobrim podešavanjem kapilarnih tlakova u pojedinim dijelovima ležišta, moguće je u prvom koraku (koji se smatra inicijalizacijskim) simulacijski postaviti zasićenja tako da se poklapaju s geofizičkim, proizvodnim i

karotaznim podatcima. Drugi primjer je pronalaženje pogrešaka u simulacijskom modelu. Naime, ako je sintaksa ulaznih datoteka u redu, i ako su ulazni podatci prošli bazičnu provjeru konzistentnosti i monotonosti, simulacijski model može davati rezultate koji u vremenu nastavljaju potpuno neprihvatljivim, tj. fizikalno nemogućim tokom. Ovakve pogreške lakše otkriva iskusni razradni inženjer, nego osoba koja je savladala tehnike i opcije simulacijskog softvera.

Naime, mnogi (ili svi) simulatori ležišta ugljikovodika funkcioniraju prema jako sličnom principu i obuhvaćaju sličan spektar vrsta simulacije, te se može reći da je savladavanjem rada u jednom lako savladati i druge. Drugim riječima, generalna definicija ulaznih podataka u različitim ležišnim simulatorima je slična, dok svaki simulator ima unikatnu sintaksu.

2.2. Laboratorijske specijalne analize jezgri stijena - relativna propusnost i kapilarni tlak

Najčešće specijalne analize jezgri stijena (engl. *Special Core Analysis, SCAL*) su mjerenja krivulje relativne propusnosti i mjerenja kapilarnog tlaka. Pri tome je standard za ispitivanja jezgra stijene promjera 3,81 *cm* (slika 2-1) i duljine 5 do 10 *cm*, koja se izrezuje iz veće jezgre (slika 2-2) uzete u bušotini procesom jezgrovanja. Ponekad, za razdvajanje faza ili pak češće prilikom utiskivanja plina i sl. potrebna je veća protočna duljina da bi se vidjeli rezultati. Tada se radi test u tankoj cijevi (engl. *slimtube test*) ili test utiskivanja na tzv. kompozitu jezgri (nizu jezgri prislonjenim jedna na drugu).




Slika 2-1 Uzorak jezgre stijene promjera 3,81 *cm*



Slika 2-2 Velika jezgra uzeta u ispitivanom intervalu bušotine

Proces jezgrovanja izvodi se u smjeru pružanja sloja ukoliko se traži horizontalna propusnost (k_h) ili okomito na smjer pružanja sloja ukoliko se ispituje vertikalna propusnost (k_v). Ovo predstavlja bitan podatak, osobito kod mjerenja apsolutne propusnosti. Vertikalna propusnost mjeri se rjeđe nego horizontalna, a u nedostatku podataka često se aproksimira sa deset puta manjom vrijednosti (Vulin, 2016).

Mjerenje relativne propusnosti izvodi se aparaturom koja se u osnovi sastoji od triaksijalnog držača jezgre, sustava za kontrolu i simulaciju petrostatskog (engl. *overburden pressure*, *OB*) i pornog tlaka (engl. *pore pressure*), protočnih vodova, kontrolnih ventila, te pokazivača sa zapornim elementom (slika 2-3).



Slika 2-3 Aparatura za mjerenje relativne propusnosti, prikaz prednje i stražnje strane

Jezgra stijene umetnuta je u držač koji se sa obje strane zatvara poklopcima sa navojnim spojem. Utiskivanje pod tlakom na površinu baza valjkastog uzorka, tj. ulazni protok u jezgru i izlazni protok iz jezgre ostvaruju se preko kanalića na poklopcu (slika 2-4).



Slika 2-4 Element koji prijanja na bazu valjka uzorka stijene, na izlaznom poklopcu držača

U simulacijskom modelu utiskivanje i proizvodnja ostvaruje se bušotinama, pa je ovakav način utiskivanja i proizvodnje nemoguće definirati u simulatoru.

Tokom eksperimenta jezgra je podložena djelovanju simuliranog petrostatskog tlaka. Istovremeno se održava i porni tlak fluida u uzorku. Stvarno opterećenje na uzorak stijene je razlika petrostatskog i pornog tlaka, te se naziva efektivni petrostatski tlak (engl. *effective overburden pressure, EOB*) (Vulin, 2016). To znači da se protok fluida u laboratorijskom ispitivanju odvija pri simuliranim istim uvjetima kao i u litosferi.

Najjednostavnije mjerenje relativne propusnosti ostvaruje se zasićivanjem jezgre do inicijalnog zasićenja sa jednim fluidom, nakon čega ga se istiskuje drugim fluidom (primjerice istiskivanje nafte sa vodom, vode sa plinom, ili nafte sa plinom). Pri tome se mjere protoci svakog od prisutnih fluida u određenim vremenskim koracima. Zatim, znajući geometrijske karakteristike uzorka, osnovna svojstva stijene i fluida te parametre eksperimenta, analitički se računaju vrijednosti relativnih propusnosti prema **Darcyjevom zakonu** (1856). Konkretna proračuna pokazana je u trećem poglavlju.

Ova metoda mjerenja naziva se "*unsteady state*" metodom, odnosno metodom neustaljenog protoka s obzirom na to da tlak protoka nije nužno konstantan i može opadati tijekom eksperimenta. U heterogenim stijenama može doći i do pojave viskoznog prstolikog probijanja (engl. *viscous fingering*).

2.3. Metode diskretizacije prostora - uspostavljanje kružne geometrije mreže ćelija


Pri diskretizaciji prostora susreće se sa raznim metodama pomoću kojih se dobiva mogućnost organizacije prostorne podjele ćelija pri simulaciji na način koji je odgovarajući za dotični problem. Principi diskretizacije su prilagođeni kako bi se najbolje mogla primijeniti metoda konačne razlike (engl. *finite-difference method*) ili metoda konačnih elemenata (engl. *finite-element method*). Dok je prva metoda jednostavna u konceptu, ipak sadrži određene mane zbog toga što je varijacijska. Metoda konačnih elemenata nadvladava poteškoće varijacijskih metoda zbog toga što provodi sistematsku proceduru derivacije aproksimacijskih funkcija, te je njen princip uzet kao odgovarajući za

suočavanje s problemom u ovome radu. Sastoji se od dvije osnovne značajke zbog kojih je superiorna nad ostalim kompetentnim metodama (Reddy, 1984):

- 1) geometrijski složene domene nekog problema se izražavaju kao skup geometrijski jednostavnijih pod-domena - konačnih elemenata (engl. *finite-elements*).
- 2) za svaki od konačnih elemenata neke geometrijske kompleksnije domene aproksimacijske funkcije se deriviraju na temelju osnovne ideje da bilo koja kontinuirana funkcija može biti predstavljena linearnom kombinacijom algebarskih polinoma. Aproksimacijske funkcije se deriviraju koristeći koncepte teorije o interpolaciji te se stoga nazivaju interpolacijskim funkcijama (engl. *interpolation functions*).

Metoda konačnih elemenata obuhvaća primjenu više varijacijskih metoda u kojima su aproksimacijske funkcije algebarski polinomi, a neodređeni parametri predstavljaju vrijednosti rješenja pri konačnom broju prethodno određenih točaka koje se nazivaju čvorovima (engl. *nodes*) te tvore granice i unutrašnjost elementa. Teorija o interpolaciji govori da stupanj interpolacijske funkcije ovisi o broju čvorova u elementu.

Koristeći koncept metode konačnih elemenata dolazi se u mogućnost određivanja geometrijski složene domene koja bi aproksimirala kružni presjek koristeći pravokutne konačne elemente. Određivanje kružnog prostora nekog poznatog radijusa, r skupom pravokutnih konačnih elemenata dovodi do mogućnosti postavljanja pravokutnih ćelija pri računalnoj simulaciji na način da geometrijski složena domena poprimi oblik valjka, poput konvencionalne jezgre stijene promjera 3,81 cm (1,5") i duljine 5 do 10 cm. S pretpostavkom da je površinu pravokutnika moguće izračunati, aproksimirana površina kruga bila bi jednaka sumi površina pravokutnih ćelija upotrijebljenih za diskretizaciju kružnog presjeka simulacijskog modela jezgre valjkastog oblika. Postoji nekoliko metoda kružne aproksimacije konačnih elemenata (slika 2-5) koji mogu biti četverokutni ali i trokutni, no za potrebe računalne simulacije u obzir se uzimaju četverokutni elementi zbog toga što je geometrijska reprezentacija simulacijskih ćelija u današnjim softverima najčešće četverokutna i u različitim izvedbama.



Slika 2-5 Primjeri primjene metode konačnih elemenata za aproksimaciju kruga (Reddy, 1984); preuređeno od Kos (2017)

Proračun aproksimacijskog područja neke domene sastoji se od nekoliko koraka pri kojima valja definirati i određene termine koji se koriste u analizama problema konačnih elemenata (Reddy, 1984):

- 1) **diskretizacija konačnog elementa** (engl. *finite-element discretization*); kontinuirano područje kruga simulacijskog modela jezgre sastoji se od skupa konačnog broja n pod skupova, odnosno pravokutnih ćelija, što se naziva diskretizacijom domene (engl. *discretization of the domain*) valjka pomoću pravokutnih ćelija, te se svaka ćelija koja tvori domenu naziva elementom (engl. *element*), a ukupan skup elemenata naziva se mrežom konačnih elemenata (engl. *finite-element mesh*). S ovom stavkom na umu, moguće je diskretizirati područje kruga u mrežu od n konačnog broja pravokutnih elemenata koji su istih dimenzija, te stoga tvore jednoliku mrežu (engl. *uniform mesh*).
- 2) **jednadžba elementa** (engl. *element equation*); tipičan pravokutnik poput simulacijske ćelije smatra se izoliranim elementom čija se prostorna svojstva poput površine ili volumena jednostavno daju izračunati. S tom premisom uvodi se zastupljujuća jednadžba za proračun prostornog područja elementa da bi se izračunalo željeno svojstvo. Za diskretizaciju domene jezgre potrebno je proračunati površinu samo jednog od elemenata A_e koji će tvoriti mrežu konačnih elemenata broja n zbog toga što je mreža jednolika, a formula koja je upotrijebljena za proračun tog svojstva glasi $A_e = a^2$ (2-1), gdje su a - duljina stranice elementa (cm), a A_e - površina elementa (cm²).
- 3) **organizacija podjele elemenata u konačno rješenje** (engl. *assembly of element equations and solution*); aproksimirana površina kruga jezgre dobivena je

postavljajući elemente poznatih površina pomoću algoritma koji je razvijen za diskretizaciju domene valjka i funkcionira na principu algebarske zakonitosti. Poznavajući radijus uzorka jezgre stijene valjkastog oblika, r ($1,882 \text{ cm} = 0,741''$), dimenzije i konačan broj n svih elemenata u mreži, adekvatno razvijenim algoritmom dolazi se u mogućnost određivanja točnih prostornih koordinata svakog elementa koji tvori mrežu konačnih elemenata na temelju graničnih uvjeta jednadžbe kružnice, $x^2 + y^2 = r^2$ (2-2), gdje su x - vrijednost granične koordinate kružnice na x -osi (cm), y - vrijednost granične koordinate kružnice na y -osi (cm), a r - vrijednost polumjera kružnice (radijus jezgre) (cm). Organizacija podjele elemenata se temelji na ideji da je konačna površina diskretizirane domene jednaka umnošku površine jednog elementa i konačnog broja n elemenata koji ju tvore, upravo zbog toga što je mreža konačnih elemenata jednolika.

- 4) **procjena pogreške i konvergencija** (engl. *convergence and error estimate*); poznavajući formulu za površinu kruga jezgre $A_o = r^2 \pi$ (2-3), gdje je A_o - površina kruga jezgre (cm^2), radijus jezgre r i površinu diskretizirane domene $A_{dsc} = \sum A_n$ (2-4), gdje su A_{dsc} - površina diskretizirane domene (cm^2), a A_n - površina n broja primijenjenih elemenata (cm^2), procjenjuje se pogreška pri diskretizaciji domene jezgre. Naime, potencijalno odstupanje diskretizirane površine od prave površine kruga poznatog radijusa prihvatljivo je za simulacijski model jezgre iz razloga što postoji ograničenost pri definiranju konačnog broja n elemenata koji će tvoriti mrežu, zbog raznih tehničkih parametara simulacije. Valja samo još napomenuti kako u teoriji, kada bi broj elemenata n težio u beskonačnost, diskretizirana površina bi uistinu bila jednaka pravoj površini kruga poznatog radijusa, odnosno došlo bi do konvergencije. Takva idealizacija nije opcionalna pri simulaciji, pa se pristupa "umanjivanju" pogreške dodavanjem elemenata da bi bila što manja, te diskretizirana površina protjecanja fluida kroz jezgru što bliža pravoj površini kruga.

Opisanim postupkom dobilo se konačno rješenje i uspostavilo se kružnu geometriju mreže pravokutnih ćelija simulacijskog modela jezgre stijene. Diskretizirana površina poprečnog presjeka jezgre iznosila je $11,09 \text{ cm}^2$, čime je odstupanje od stvarne površine baze uzorka koja iznosi $11,13 \text{ cm}^2$, bilo $0,04 \text{ cm}^2$ odnosno $0,4 \%$. Trodimenzionalni prikaz modela bit će prikazan u četvrtom poglavlju, a svi podaci o uzorku u trećem poglavlju.

2.4. Struktura simulacijskog modela - organizacija ulaznih podataka

Većina sofisticiranih komercijalnih simulatora, uključujući i ECLIPSE (Schlumberger, 2014), funkcionira na principu definiranja ulaznih podataka, tj. inicijalizacije modela, zatim na principu numeričkog izračuna promjene tlakova i zasićenja s promjenom vremena, te na principu promjene početno zadanog modela kako bi rezultatni podatci davali smislenu sliku modelom zadanog procesa (protoka kroz jezgru, proizvodnje na razini ležišta, utiskivanja fluida, itd.). Ovakav opis fizikalnog sustava moguć je postavljanjem zakonitosti za protok fluida kroz porozni medij u programskom jeziku, konkretnije simulator ECLIPSE napisan je programskim jezikom FORTRAN (Schlumberger, 2014).

Datoteka s bazom ulaznih podataka (engl. *input data file*) potrebnih za inicijalizaciju simulacijskog modela sastoji se od nekoliko neophodnih sekcija (engl. *section*) u kojima se na temelju sintakse ključnih riječi (engl. *keywords*) definiraju svojstva modela. S obzirom na to da je proces inicijalizacije modela (kako bi se dobila funkcionalna konačna verzija koja reprezentativno opisuje laboratorijski test) ključan ali i izazovan aspekt rada, valja ukratko opisati općenitu strukturu simulacijskog modela.

Simulacijski model u osnovi se sastoji od početne sekcije (RUNSPEC) u kojoj se definiraju osnovni parametri modela, poput vrste i broja ćelija od kojih će se sastojati, faza za koje će se simulirati protok, tipa mjernih jedinica koje će se koristiti, imena modela, datuma početka proizvodnje i sl.

Zatim slijedi sekcija o sustavu ćelija (GRID) koja je važna s obzirom na to da simulacijske ćelije aproksimiraju stvaran fizikalni sustav ležišne stijene, njenih svojstava i geometrijskih karakteristika. Postoji više vrsta ćelija s obzirom na koordinatni sustav ili na način na koji se one same po sebi geometrijski definiraju. Za model u ovom radu korištene su ćelije definirane kartezijskim koordinatnim sustavom koje su geometrijski pravokutnog oblika (engl. *block-centered grid*). Za svaku ćeliju u modelu potrebno je zadati dimenzije u sva tri smjera kartezijskog koordinatnog sustava, dubinu na kojoj se svaka ćelija nalazi, zatim propusnosti u smjeru X , Y i Z osi, te poroznost stijene. Prema osnovnim simulacijskim postavkama sve ćelije definirane u modelu smatrane su aktivnima za protok

fluida, no ukoliko je potrebno ukloniti segmente simulacijske mreže moguće je odrediti ćelije koje neće biti aktivne tijekom simulacije.

Zatim slijedi sekcija PROPS u kojoj se zadaju podatci relativnih propusnosti i kapilarnog tlaka u odnosu na zasićenje fluidima i pVT svojstva za svaki fluid koji je modelom definiran kao prisutna faza u protoku (sekcijom RUNSPEC), te osnovna fizikalna svojstva (gustoće fluida, kompresibilnost stijene, viskoznost).

Iduća sekcija je SOLUTION u kojoj je podatke za inicijalizaciju modela moguće zadati različitim metodama. "*Equilibrium*" metoda predstavlja algoritam kojim simulator proračunava inicijalne uvjete zasićenja fluida u ležištu na temelju kontakta nafte i vode u ležištu i tlakova u ležištu, te podataka zadanih u PROPS sekciji. "*Enumeration*" metodom moguće je samostalno odrediti tlakove i inicijalna zasićenja za svaku ćeliju u modelu. U slučaju kada su vrijednosti određene pod kontroliranim uvjetima (primjerice u laboratoriju), pouzdanije je zadati podatke o inicijalnim uvjetima tlaka i zasićenja fluidima u modelu "*Enumeration*" metodom iz razloga što "*Equilibrium*" metodom može doći do pogrešnog proračuna kod modela malih dimenzija (simulacijski mikro model jezgre) s obzirom da su simulatori prilagođeni makro dimenzijama (ležišta). "*Enumeration*" metoda ne preporučuje se za ležišne modele jer su po svojstvima tlačne raspodjele i raspodjele zasićenja nekonzistentni i model inicijaliziran jednoličnim inicijalnim uvjetima zasigurno bi doveo do pogrešnog proračuna protoka.

Zatim slijedi sekcija SUMMARY u kojoj se određuje izlazne parametre simulacije (rezultate) koje će simulator generirati u odredišnoj datoteci (podatci o proizvodnji fluida, zasićenjima tokom simulacije, tlakovima u ležištu i sl.).

Posljednja sekcija je SCHEDULE u kojoj se definiraju bušotine u modelu, podatci o opremanju bušotina, parametri proizvodnje i utiskivanja, te vremenski korak kroz koji će simulacija "napredovati".

2.5. Korelacija krivulje relativnih propusnosti za simulacijski model

Često je u praksi poznat slučaj da se za potrebe numeričkog modeliranja ležišta krivulja relativnih propusnosti mora mijenjati prema nekoj od priznatih korelacija. Za svrhu ovog istraživanja korištena je korelacija koju su **Brooks** i **Corey** (1964) dali prema sljedećim izrazima:

$$k_{ro} = k_{ro, \max} \left(\frac{S_o - S_{or}}{1 - S_{or} - S_{wc} - S_{gc}} \right)^{n_o} \quad (2-5)$$

$$k_{rw} = k_{rw, \max} \left(\frac{S_w - S_{wc}}{1 - S_{or} - S_{wc} - S_{gc}} \right)^{n_w} \quad (2-6)$$

$$k_{rg} = k_{rg, \max} \left(\frac{S_g - S_{gc}}{1 - S_{or} - S_{wc} - S_{gc}} \right)^{n_g} \quad (2-7)$$

gdje su:	k_{ro}	- relativna propusnost nafte
	$k_{ro, \max}$	- maksimalna vrijednost relativne propusnosti nafte
	k_{rw}	- relativna propusnost vode
	$k_{rw, \max}$	- maksimalna vrijednost relativne propusnosti vode
	k_{rg}	- relativna propusnost plina
	$k_{rg, \max}$	- maksimalna vrijednost relativne propusnosti plina
	S_o	- zasićenje naftom
	S_{or}	- rezidualno zasićenje naftom
	S_w	- zasićenje vodom
	S_{wc}	- konatno, intersticijalno, inicijalno zasićenje vodom
	S_g	- zasićenje plinom
	S_{gc}	- konatno zasićenje plinom
	n_o	- eksponent za naftu
	n_w	- eksponent za vodu
	n_g	- eksponent za plin

U opisu ove korelacije navedeno je da eksponenti za naftu, vodu i plin mogu varirati od 1 do 6, a maksimalne vrijednosti relativnih propusnosti za naftu, vodu i plin mogu varirati između 0 i 1.

3. INTERPRETACIJA ULAZNIH PODATAKA LABORATORIJSKOG EKSPERIMENTA - ANALITIČKI PRORAČUN

Na raspolaganju su bili dostupni podatci *SCAL* mjerenja iz laboratorija INA d.d. za ispitivanje stijena i ležišnih fluida, sa svim potrebnim parametrima za inicijalizaciju simulacijskog modela. Prvi set podataka takvog eksperimenta uključuje osnovna svojstva stijena i fluida, geometrijske karakteristike uzorka jezgre stijene i druge tehničke parametre (tablica 3-1).

Tablica 3-1 Set podataka o svojstvima stijena i fluida, karakteristikama uzorka i eksperimenta

Duljina	L	cm	6,59
Površina poprečnog presjeka	A	cm ²	11,13
Volumen	V	cm ³	73,35
Promjer	D	cm	3,76
Poroznost	Φ	%	19
Porni volumen	P.V.	cm ³	13,94
Inicijalno zasićenje vodom	S _{wi}	% (P.V.)	23,3
Inicijalno zasićenje naftom	S _{oi}	% (P.V.)	76,7
Propusnost (apsolutna)	k	mD	57,9
Propusnost za naftu pri S_{wi}	k _o @ S _{wi}	mD	30,71
Propusnost za vodu pri S_{or}	k _w @ S _{or}	mD	11,8
Tlak eksperimenta	Δp	bar	7,75
Simulirani tlak naslaga	OB	bar	100
Inicijalni volumen vode u porama stijene	V _{wi-p.v.}	cm ³	3,25
Inicijalni volumen nafte u porama stijene	V _{oi-p.v.}	cm ³	10,69
Salinitet (NaCl) vode	S	g/l	29
Gustoća vode	ρ_w	g/cm ³	1,0182
Gustoća nafte	ρ_o	g/cm ³	0,8416
Viskoznost vode	μ_w	mPas	0,966
Viskoznost nafte	μ_o	mPas	24,3
Temperatura vode	T _w	°C	26
Temperatura nafte	T _o	°C	26
Korekcijski volumen zbog stlačivosti	V _{kor}	cm ³	0,4

Razlika tlaka za naftu	Δp_o	bar	11,5
Razlika tlaka za vodu	Δp_w	bar	7,75
Volumetrijski protok nafte	Q_o	cm ³ /min	10
Volumetrijski protok vode	Q_w	cm ³ /min	20
Konačan iscrpak ulja	V_o	cm ³	6,62

Drugi set podataka uključuje mjerene laboratorijske vrijednosti dvofaznog protoka fluida kroz jezgru stijene tokom eksperimenta koji je trajao 107,5 minuta (tablica 3-2). U ovom testu, jezgra je prethodno bila maksimalno zasićena sa naftom. Utiskivanjem vode istiskivala se nafta iz uzorka. Cjelokupni eksperiment kvantitativno je praćen kroz 13 vremenskih koraka u kojima je izmjeren volumen nafte i nafte i vode na izlazu iz jezgre.

Volumen vode izračunat je prema izrazu:

$$V_w = V_{o+w} - V_o \quad (3-1)$$

gdje su:

- V_w - volumen vode (cm³)
- V_{o+w} - volumen nafte i vode (cm³)
- V_o - volumen nafte (cm³)

Tablica 3-2 Set podataka mjerenih laboratorijskih vrijednosti dvofaznog protoka laboratorijskog ulja i vode

Broj mjerenja	Vrijeme kumulativno t (min)	Vrijeme kumulativno t (h)	Vremenski korak t (h)	Ulje kumulativno V_o (cm ³)	Ulje+voda kumulativno V_{o+w} (cm ³)	Voda kumulativno V_w (cm ³)
0	0	0	0	0	0	0
1	2,37	0,0395	0,03950	2,62	2,65	0,03
2	3,2	0,0533333	0,01383	3,07	3,96	0,89
3	4,35	0,0725	0,01917	3,42	6,16	2,74
4	5,73	0,0955	0,02300	3,73	9,31	5,58
5	7,28	0,1213333	0,02583	4	13,51	9,51
6	8,96	0,1493333	0,02800	4,22	18,73	14,51
7	12	0,2	0,05067	4,57	29,78	25,21
8	16,92	0,282	0,08200	4,97	50,93	45,96
9	26,5	0,4416667	0,15967	5,4	101,88	96,48
10	41,75	0,6958333	0,25417	5,74	203,1	197,36
11	66,6	1,11	0,41417	6,01	404,22	398,21
12	87,87	1,4645	0,35450	6,21	605,42	599,21
13	107,5	1,7916667	0,32717	6,32	806,88	800,56
				6,62		

Na temelju osnovnih ulaznih podataka prikazanih u tablicama 3-1 i 3-2 analitičkim proračunom utvrdilo se treći set podataka o zasićenjima fluida, relativnim propusnostima i drugim parametrima (tablica 3-3).

Prvobitno je izračunat volumen nafte u porama jezgre (porni volumen nafte) tijekom testa oduzimanjem izmjerenih proizvodnih volumena nafte od inicijalnog pornog volumena nafte u jezgri za svaki stupanj mjerenja prema izrazu:

$$V_{o-p.v.} = V_{oi-p.v.} - V_o \quad (3-2)$$

gdje su: $V_{o-p.v.}$ - porni volumen nafte (cm³)
 $V_{oi-p.v.}$ - inicijalni porni volumen nafte (cm³)

Na temelju vrijednosti pornih volumena nafte u odnosu na ukupni porni volumen stijene izračunata su zasićenja naftom u jezgri za svaki vremenski korak tijekom testa prema izrazu:

$$S_o = \frac{V_{o-p.v.}}{P.V.} \quad (3-3)$$

gdje su: S_o - zasićenje naftom
 $P.V.$ - porni volumen stijene (cm^3)

Shodno zasićenjima naftom, izračunate su vrijednosti zasićenja vodom tijekom testa za svaki korak praćenja prema izrazu:

$$S_w = 1 - S_o \quad (3-4)$$

gdje je: S_w - zasićenje vodom

Nadalje, da bi se proračunale relativne propusnosti za naftu i vodu, potrebno je bilo odrediti efektivne propusnosti za svaki fluid prema **Darcyjevom zakonu** (1856):

$$k_{o-eff} = \frac{\mu_o \cdot q_o \cdot L}{A \cdot \Delta p} \quad (3-5)$$

$$k_{w-eff} = \frac{\mu_w \cdot q_w \cdot L}{A \cdot \Delta p} \quad (3-6)$$

gdje su: k_{o-eff} - efektivna propusnost nafte (cm^2)
 k_{w-eff} - efektivna propusnost vode (cm^2)
 μ_o - viskoznost nafte ($Pa \cdot s$)
 μ_w - viskoznost vode ($Pa \cdot s$)
 q_o - volumetrijski protok nafte (cm^3/s)
 q_w - volumetrijski protok vode (cm^3/s)
 A - površina poprečnog presjeka jezgre stijene (cm^2)
 L - duljina jezgre stijene (cm)
 Δp - razlika tlakova na ulazu i izlazu iz jezgre (Pa)

Vidi se kako se u analitičkom proračunu razlika tlaka pretpostavlja konstantnom vrijednosti, dok u stvarnosti to ne mora biti slučaj s obzirom na to da se radi o "*unsteady state*" metodi mjerenja, u kojoj nije nužno konstantan tlak protoka i može doći do viskoznog prstolikog probijanja (engl. *viscous fingering*). Tako da je teško i procijeniti pravi stupanj preciznosti za vrijednosti relativnih propusnosti koje su dobivene ovakvim laboratorijskim testiranjima.

Kroz svaki vremenski korak jedini parametar **Darcyjeve** jednadžbe koji se mijenja je volumetrijski protok za svaki od fluida, i on uvjetuje vrijednosti efektivnih propusnosti.

Konačno, pomoću dobivenih efektivnih propusnosti nafte i vode, izračunalo se vrijednosti relativnih propusnosti za svaki fluid prema sljedećim izrazima:

$$k_{ro} = \frac{k_{o-eff}}{k} \quad (3-7)$$

$$k_{rw} = \frac{k_{w-eff}}{k} \quad (3-8)$$

gdje su:	k_{ro}	- relativna propusnost nafte
	k_{rw}	- relativna propusnost vode
	k	- apsolutna propusnost stijene (cm^2)

Granične točke zasićenja (engl. *saturation endpoints*)

Relativna propusnost za naftu pri inicijalnom zasićenju vodom ($S_{wi}=0,233$) dobivena je omjerom specifične, tj. kritične propusnosti za naftu ($k_o@S_{wi}$) i apsolutne propusnosti uzorka, te iznosi 0,53. U istom trenutku relativna propusnost vode, jednaka je nuli. Inicijalno zasićenje naftom jednako je 0,767.

Relativna propusnost za vodu pri rezidualnom zasićenju sa naftom ($S_{or}=0,29$) dobivena je omjerom kritične propusnosti za vodu ($k_w@S_{or}$) i apsolutne propusnosti uzorka, te iznosi 0,2. Relativna propusnost nafte tada je nula. Maksimalno zasićenje vodom iznosi 0,71.

Kao zadnja stavka analitičkog proračuna, utvrđene su vrijednosti frakcijskog protoka vode tijekom eksperimenta, na temelju sljedećeg izraza:

$$f_w = \frac{q_w}{q_o + q_w} \quad (3-9)$$

gdje je: f_w - frakcijski protok vode


Tablica 3-3 Analitički proračunat set podataka o relativnim propusnostima u odnosu na zasićenje fluidima

Porni volumen nafte $V_{o-p.v.} (cm^3)$	Zasićenje naftom S_o	Zasićenje vodom S_w	Efektivna propusnost nafte $k_{o-eff} (mD)$	Efektivna propusnost vode $k_{w-eff} (mD)$	Relativna propusnost nafte k_{ro}	Relativna propusnost vode k_{rw}	Frakcijski protok vode f_w
	0,767	0,233			0,53	0	0
8,07	0,58	0,42	23,05	0,02	0,40	0,0003	0,011
7,62	0,55	0,45	20,00	0,34	0,35	0,006	0,656
7,27	0,52	0,48	16,39	0,77	0,28	0,013	0,841
6,96	0,50	0,50	13,57	1,20	0,23	0,021	0,902
6,69	0,48	0,52	11,46	1,61	0,20	0,028	0,936
6,47	0,46	0,54	9,82	1,99	0,17	0,034	0,958
6,12	0,44	0,56	7,94	2,58	0,14	0,045	0,968
5,72	0,41	0,59	6,12	3,34	0,11	0,058	0,981
5,29	0,38	0,62	4,25	4,48	0,073	0,077	0,992
4,95	0,36	0,64	2,87	5,81	0,050	0,10	0,997
4,68	0,34	0,66	1,88	7,35	0,032	0,13	0,999
4,48	0,32	0,68	1,47	8,39	0,025	0,14	0,999
4,37	0,31	0,69	1,23	9,16	0,021	0,16	0,999
4,07	0,29	0,71			0	0,20	1,000

4. SIMULACIJSKI MODEL SPECIJALNIH ANALIZA JEZGRE STIJENE - MODELIRANJE I REZULTATI


4.1. Model broj 1 (5x25x25 LAB)

Prvi model inicijaliziran je koristeći vrijednosti laboratorijskih krivulja relativnih propusnosti u odnosu na zasićenje fluidom, odnosno krivulja utvrđenih analitičkim proračunom na temelju laboratorijskih podataka (slika 4-1).




Slika 4-1 Krivulje relativnih propusnosti utvrđene laboratorijskom analizom

Model se geometrijski sastojao od 5 ćelija u smjeru osi X i 25 ćelija u smjeru osi Y i Z (5x25x25). Trodimenzionalni prikaz ovog modela i geometrije koja je korištena može se vidjeti na slici 4-2.




Slika 4-2 3D prikaz geometrije modela broj 1 (5x25x25 LAB) (t=1 min)

Prije toga testirana je bila i mreža ćelija 5x51x51 zbog preciznije diskretizacije površne poprečnog presjeka jezgre (slika 4-3), no ustanovljeno je kako je zadovoljavajuće koristiti manji broj ćelija s obzirom na to da je potrebno odabrati optimalan broj ćelija u skladu sa dimenzijama modela koji će ponekad voditi i do boljih rezultata.



Slika 4-3 3D prikaz testirane geometrije (5x51x51) za model broj 1

Model je davao krivulju proizvodnih vrijednosti koja je previše odstupala od željenih rezultata. Rezultat proizvodnje nafte numeričkom simulacijom (zeleno krivulja) usporedno je prikazan sa laboratorijski mjerenim vrijednostima koje su prikazane crnim točkama (slika 4-4). Generalno model je postupno proizvodio previše nafte od treće do četrdeset i treće minute eksperimenta, nakon čega je uslijedila konstantna vrijednost prevelikog iscrpka do kraja testa.



Slika 4-4 Usporedni prikaz proizvodnje nafte prvog modela (5x25x25 LAB) i laboratorijski mjerenih vrijednosti

Već u ovom stupnju ispitivanja bilo je jasno da će biti potrebno prilagoditi krivulju relativnih propusnosti kako bi se uskladili proizvodni rezultati. Zatim se pokušalo podešavanjem parametra transmisibilnosti u istom modelu dobiti bolji rezultat (tamnoplava krivulja), što se pokazalo kao validnom pretpostavkom, ali također je rezultiralo ne sasvim reprezentativnim opisom eksperimenta. Zatim se pristupilo podešavanju nekoliko zadnjih točaka krivulje relativne propusnosti za naftu, pa uvođenju većeg broja točaka pri početnom momentu mjerenja kako bi krivulja bila detaljnija, no niti jedna od ovih metoda nije rezultirala uspješnom približavanju proizvodnih rezultata u odnosu na prvobitno određenu krivulju laboratorijskom analizom.


Vrijednosti proizvodnih podataka kroz vremenske korake usporedno su prikazane tablicom 4-1, gdje se relativnom pogreškom odredilo odstupanja podataka mjerenih od simuliranih vrijednosti.

Pri tome valja napomenuti kako je za vrijeme trajanja eksperimenta simulator generirao detaljnije rješenje za protok fluida u odnosu na praćenje koje se odvijalo u laboratoriju. Konkretnije, simulacijsko rješenje za protok kvantitativno je generirano kroz 109 vremenskih koraka u odnosu na laboratorijsko praćenje protoka koje se odvijalo kroz 13 vremenskih koraka. Drugim riječima, modelom je svrsishodno postavljeno da simulacija zadanog procesa napreduje kroz svaku minutu trajanja laboratorijskog eksperimenta kako bi numerički proračun dao točnije (detaljnije) rješenje. Nedostatak je naime predstavljao problem što se nekoliko točaka vremenskog koraka laboratorijskog eksperimenta i simulatora međusobno nije podudaralo (da bi se usporedilo proizvodne vrijednosti) pa se u tu svrhu pristupilo metodama interpolacije i ekstrapolacije (funkcijom TREND) simuliranih podataka kako bi se odredilo egzaktnu vrijednost simuliranog protoka za dani vremenski korak laboratorijskog praćenja, čime je omogućena konkretna međusobna usporedba.

Tablica 4-1 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 1 (5x25x25 LAB) od laboratorijskog eksperimenta

Broj mjerenja	Vrijeme t (h)	Vrijeme t (min)	Proizvedena nafta laboratorij V _o (cm ³)	Proizvedena nafta simulacijski V _o (cm ³)	Relativna pogreška (%)	Proizvedena nafta simulacijski (transmisibilnost) V _o (cm ³)	Relativna pogreška (%)
0	0	0	0	0	0	0	0
1	0,040	2,37	2,62	2,318	-12	0,750	-71
2	0,053	3,2	3,07	3,414	11	1,029	-66
3	0,073	4,35	3,42	4,187	22	1,417	-59
4	0,096	5,73	3,73	4,700	26	1,890	-49
5	0,121	7,28	4	5,152	29	2,418	-40
6	0,149	8,96	4,22	5,524	31	2,965	-30
7	0,200	12	4,57	5,928	30	3,665	-20
8	0,282	16,92	4,97	6,292	27	4,366	-12
9	0,442	26,5	5,4	6,6	22	5,26	-3
10	0,696	41,75	5,74	6,64	16	5,99	4
11	1,110	66,6	6,01	6,65	11	6,5	8
12	1,465	87,87	6,21	6,65	7	6,63	7
13	1,792	107,5	6,32	6,65	5	6,65	5

Frakcijski protok fluida kojime se istiskivalo naftu prikazan je na slici 4-5 gdje se može vidjeti usporedan prikaz simulacijskih vrijednosti sa laboratorijskim.



Slika 4-5 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (5x25x25 LAB)

Najpreciznije usklađivanje proizvodne krivulje postiže se upravo i najlakše, prilagođavanjem krivulje relativnih propusnosti koja predstavlja najbitniji parametar kada se radi o protoku fluida na pornoj razini. Nadalje, mnogo je parametara koji direktno uvjetuju proizvodne vrijednosti simulacijskog modela (poput geometrije modela, tlakovi na dnu bušotina (engl. *Bottom Hole Pressure, BHP*), dimenzije ćelija, transmisibilnost stijene, i dr.), no idealan je slučaj kada su u modelu takve vrijednosti fiksno definirane, na način da reprezentativno opisuju sustav koji se simulira, dok se izmjenom podataka samo o relativnoj propusnosti (i/ili kapilarnom tlaku) pristupa podešavanju rezultata.

4.2. Model broj 2 (5x25x25)

Drugim modelom prilagođavane su sve vrijednosti krivulje relativnih propusnosti za naftu i vodu u skladu sa Corey-Brooks tipom korelacije. Model se geometrijski sastojao od

iste mreže ćelija (5x25x25) kao i prvi koji je testiran, a prostorno se geometrijski može vidjeti na slici 4-2.

Bitno je napomenuti da su pri ovom procesu, kritična zasićenja (koja "predstavljaju" takozvane "*end efekte*") ostavljena istima kakva su određena laboratorijskom analizom, kako bi model numeričke simulacije bio reprezentativan prema svim parametrima laboratorijskog eksperimenta, iako ostaje upitno koliko bi se moglo mijenjati "*end*" efekte zbog već spomenutih efekata „kašnjenja“.

Naime, postupak promjene krivulje relativnih propusnosti prema izrazima korelacije koji su prikazani u drugom poglavlju, provodi se na način da zasićenja s dotičnim fluidom kroz određeni vremenski korak dobivena interpretacijom laboratorijske analize predstavljaju fiksne vrijednosti, dok je eksponente korelacije moguće mijenjati kako bi se dobio željeni nagib krivulja relativnih propusnosti, te eventualno promijeniti i kritična zasićenja.


Kritična zasićenja u slučaju ovog ispitivanja ostavljena su također fiksima, iz razloga što simulator na temelju tih podataka proračunava inicijalne uvjete zasićenja, odnosno volumena fluida koji se početno nalazi u porama stijene (FOIP, FWIP). Naime, važno je da podatak o početnim količinama fluida u porama stijene simulacijskog modela bude istovjetan stvarnom sustavu kojega se opisuje s obzirom na to da on izravno uvjetuje proizvodne količine fluida.

Sada se, navedenom analogijom rada praktično moglo usporediti simulacijski dobivene vrijednosti početne količine fluida u stijeni (engl. *Oil originally in place, OOIP*) s onima koje su analitički utvrđene laboratorijskom analizom. Vrijednosti su se poklapale s relativno zanemarivim odstupanjem (druga decimala) čime je potvrđeno kako je uspostavljena diskretizirana geometrija kružnog presjeka modela koji se sastoji od pravokutnih ćelija sasvim precizna i opravdano točna, s obzirom na to da je volumen pora jednak umnošku ukupnog volumena stijene i poroznosti stijene .

Način kojim se pomoću Corey-Brooks korelacije pristupilo usklađivanju proizvodnih rezultata (engl. *history matching*) bio je da se određivalo vrijednosti eksponenata korelacije za naftu i vodu koji uvjetuju nagib krivulja potreban da se proizvodna krivulja nafte uskladi sa laboratorijskim vrijednostima, pri čemu se potreban nagib dobije testiranjem različitih vrijednosti eksponenata.

Generalno, smanjenjem eksponenta za naftu ili vodu u korelaciji povećavaju se vrijednosti krivulje relativnih propusnosti, čime je moguće ostvariti veću proizvodnju fluida, dok se povećavanjem pripadajućih eksponenata u korelaciji smanjuju vrijednosti krivulje relativnih propusnosti, čime je moguće dobiti manju proizvodnju fluida, pa je poznavajući ovakav "uzorak" ponašanja modela moguće u samo nekoliko trenutaka vrlo precizno uskladiti podatke.

Opisanim procesom prilagodbe k_{ro} i k_{rw} krivulja modelom broj 2 uspješno se uskladilo i dobilo proizvodne vrijednosti koje su prikazane slikom 4-6.



Slika 4-6 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela broj 2 (5x25x25)


Vrijednosti proizvodnih podataka kroz vremenske korake usporedno su prikazane tablicom 4-2, gdje se relativnom pogreškom odredilo odstupanja podataka mjerenih od simuliranih vrijednosti, istom analogijom rada kao i za prethodni model.

Tablica 4-2 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 2 (5x25x25) od laboratorijskog eksperimenta

Broj mjerjenja	Vrijeme t (h)	Vrijeme t (min)	Proizvedena nafta laboratorij V _o (cm ³)	Proizvedena nafta simulacijski V _o (cm ³)	Relativna pogreška (%)
0	0	0	0	0	0
1	0,040	2,37	2,62	2,249	-14
2	0,053	3,2	3,07	2,640	-14
3	0,073	4,35	3,42	3,082	-10
4	0,096	5,73	3,73	3,511	-6
5	0,121	7,28	4	3,855	-4
6	0,149	8,96	4,22	4,153	-2
7	0,200	12	4,57	4,537	-1
8	0,282	16,92	4,97	4,971	0
9	0,442	26,5	5,4	5,420	0
10	0,696	41,75	5,74	5,800	1
11	1,110	66,6	6,01	6,063	1
12	1,465	87,87	6,21	6,182	0
13	1,792	107,5	6,32	6,262	-1


Prema prikazanim podacima vidi se kako u početnim momentima mjerenja rezultati odstupaju većim intenzitetom nego što je to u kasnijoj fazi eksperimenta.

Krivulje relativnih propusnosti koje su upotrijebljene za ovaj model prikazane su na slici 4-7.



Slika 4-7 Krivulje relativnih propusnosti prilagođene prema Corey-Brooks korelaciji za model broj 2 (5x25x25)

Frakcijski protok fluida kojime se istiskivalo naftu prikazan je na slici 4-8 gdje se može vidjeti usporedan prikaz simulacijskih vrijednosti sa laboratorijskima.




Slika 4-8 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (5x25x25)

4.3. Model broj 3 (25x25x25)

Trećim modelom koji je inicijaliziran, pokušalo se povećati broj ćelija u smjeru osi X , dakle kroz smjer protoka fluida po duljini jezgre, s obzirom na to da je upravo taj parametar i bitan kad se radi o protoku kroz uzorak, koji uključuje kapilarni tlak, protočna svojstva fluida (efektivne propusnosti za svaki prisutan fluid, transmisibilnost stijene, heterogenost poroznosti), te fizikalna svojstva koja se očituju na pornoj razini (engl. *pore scale*) (površinska napetost, močivost).

Prvobitno je testirana mreža od 50 ćelija po osi X (50x25x25), no ovdje je dolazilo do problema koji uključuje tehničke parametre, konkretnije promjer utisne i proizvodne bušotine. Naime, s obzirom na to da je jezgra stijene malih dimenzija, nije ju sasvim praktično opisati sa većim brojem ćelija iz razloga što je istovremeno potrebno smanjiti dimenzije svake ćelije. Konkretnije, jezgra stijene na kojoj su se obavljala laboratorijska testiranja bila je duljine 6,59 cm. To znači da 50 ćelija po smjeru osi X moraju biti dimenzionirane na 0,1318 cm po ćeliji. Promjer jezgre iznosio je 3,76 cm. Dakle 25 ćelija po smjeru osi Y i Z dimenzionirane su na 0,1506 cm po ćeliji. Tako zadane vrijednosti za promjere bušotina koji moraju biti manji od dimenzija ćelije odudaraju od vrijednosti za kakve je dimenzioniran simulator ECLIPSE, te je moguće dobiti simulirane fizikalno neutemeljene rezultate koji nastaju najčešće zbog numeričke disperzije (odstupanja numeričkih rješenja zbog premalog broja iteracija ili loše definiranih dimenzija između susjednih ćelija).

Zatim se pokušalo smanjiti broj ćelija na 25 po osi X , dakle inicijaliziralo se model (25x25x25) (slika 4-9), čime je uspješno izvedena simulacija, koja je već u ovom slučaju ipak zahtijevala malo više procesorskog vremena (engl. *runtime*), jer se grid sada već sastojao od ukupno 15 625 ćelija.



Slika 4-9 Trodimenzionalni prikaz geometrije modela broj 3 (25x25x25) (t=2,22 min)


S obzirom na idealniju geometriju modela broj 3 u odnosu na prethodna dva, ponovo se testiralo krivulje relativnih propusnosti određene laboratorijskom analizom kako bi se usporedilo rezultate, čime je uočen sličan uzorak prevelikih proizvodnih vrijednosti kao i sa modelom broj 1. Nadalje, s obzirom na to da laboratorijske krivulje nisu normalizirane, pokušalo se uskladiti proizvodne vrijednosti normalizacijom krivulja relativne propusnosti za naftu i vodu prema sljedećem izrazu:

$$k_{r \text{ norm}(S = n)} = \frac{k_{r \text{ max}}}{k_{r(n)}} \quad (4-1)$$

gdje su:

- $k_{r \text{ norm}(S=n)}$ - normalizirana vrijednost relativne propusnosti za n točku zasićenja fluidom
- $k_{r \text{ max}}$ - maksimalna vrijednost relativne propusnosti
- $k_{r(n)}$ - relativna propusnost pri točki n zasićenja fluidom

Normalizacija laboratorijskih krivulja rezultirala je približavanjem rezultata proizvodnih vrijednosti eksperimenta u odnosu na slučaj kada nisu normalizirane, a usporedan prikaz rezultata može se vidjeti na slici 4-10.



Slika 4-10 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela 3 (25x25x25) inicijaliziranog laboratorijskim krivuljama

Zaključno se potvrdilo kako krivulje dobivene laboratorijskim analizama općenito nisu idealne za simulaciju, pri čemu ih se normalizacijom postavlja u formu koja je više prigodna za simulator, a zatim ih je moguće prilagoditi korelacijom (engl. *data tuning*) kako bi se uskladili rezultati.


Vrijednosti proizvodnih podataka kroz vremenske korake usporedno su prikazane tablicom 4-3, gdje se relativnom pogreškom odredilo odstupanja podataka mjerenih od simuliranih vrijednosti.

Tablica 4-3 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 3 (25x25x25 LAB) od laboratorijskog eksperimenta

Broj mjerjenja	Vrijeme t (h)	Vrijeme t (min)	Proizvedena nafta laboratorij V_o (cm ³)	Proizvedena nafta simulacijski V_o (cm ³)	Relativna pogreška (%)	Proizvedena nafta simulacijski - normalizirano V_o (cm ³)	Relativna pogreška (%)
0	0	0	0	0	0	0	0
1	0,040	2,37	2,62	1,81	-31	3,18	22
2	0,053	3,2	3,07	2,58	-16	3,94	28
3	0,073	4,35	3,42	3,77	10	4,62	35
4	0,096	5,73	3,73	4,71	26	5,19	39
5	0,121	7,28	4	5,27	32	5,62	41
6	0,149	8,96	4,22	5,73	36	5,92	40
7	0,200	12	4,57	6,27	37	6,23	36
8	0,282	16,92	4,97	6,70	35	6,50	31
9	0,442	26,5	5,4	7,15	32	6,62	23
10	0,696	41,75	5,74	7,34	28	6,63	15
11	1,110	66,6	6,01	7,36	22	6,63	10
12	1,465	87,87	6,21	7,36	19	6,63	7
13	1,792	107,5	6,32	7,36	16	6,63	5

Zatim se koristeći Corey-Brooks korelaciju istom analogijom rada kao i za prethodni model broj 2 (5x25x25) pristupilo detaljnijem usklađivanju proizvodnih podataka, pri čemu je uočeno da su potrebne različite krivulje relativnih propusnosti za naftu i vodu u odnosu na model broj 2 kako bi se uspješno uskladili rezultati. Naime, uspostavljanjem različite aproksimacije sustava ćelija između drugog i trećeg modela, koja uključuje i različito dimenzioniranje tih ćelija, došlo je do drugačije raspodjele isto zadanih fizikalnih svojstava, čime se može reći da su ta dva modela neznatno međusobno heterogeni. Vidi se kako je model na tako malim i preciznim dimenzijama vrlo osjetljiv i na najmanje promjene ulaznih parametara, čime je izravno potvrđeno kako su svojstva opisiva na razini pora važan pokazatelj protoka fluida u nekom ležištu i da uvelike na njega utječu, naime što je istovjetno i stvarnom fizikalnom sustavu.

Dakle, modelom broj 3 (25x25x25) koji uključuje različite inicijalizacijske parametre relativnih propusnosti prema Corey-Brooks korelaciji, dobivena je preciznija raspodjela proizvodnih vrijednosti u prvih 20 minuta laboratorijskog eksperimenta u odnosu na model broj 2, a usporedni prikaz trećeg modela i laboratorijski mjerenih vrijednosti može se vidjeti na slici 4-11.




Slika 4-11 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela 3 (25x25x25) inicijaliziranog krivuljama korelacije

Vrijednosti proizvodnih podataka kroz vremenske korake usporedno su prikazane tablicom 4-4, gdje se relativnom pogreškom odredilo odstupanja podataka mjerenih od simuliranih vrijednosti.

Tablica 4-4 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 3 (25x25x25 Corey-Brooks) od laboratorijskog eksperimenta


Broj mjerjenja	Vrijeme t (h)	Vrijeme t (min)	Proizvedena nafta laboratorij V _o (cm ³)	Proizvedena nafta simulacijski V _o (cm ³)	Relativna pogreška (%)
0	0	0	0	0	0
1	0,040	2,37	2,62	2,431	-7
2	0,053	3,2	3,07	2,891	-6
3	0,073	4,35	3,42	3,352	-2
4	0,096	5,73	3,73	3,700	-1
5	0,121	7,28	4	3,959	-1
6	0,149	8,96	4,22	4,209	0
7	0,200	12	4,57	4,552	0
8	0,282	16,92	4,97	4,924	-1
9	0,442	26,5	5,4	5,330	-1
10	0,696	41,75	5,74	5,758	0
11	1,110	66,6	6,01	6,105	2
12	1,465	87,87	6,21	6,278	1
13	1,792	107,5	6,32	6,397	1

Krivulje relativnih propusnosti korištene za treći model prikazane su na slici 4-12.



Slika 4-12 Krivulje relativnih propusnosti prilagođene prema Corey-Brooks korelaciji za model broj 3 (25x25x25)


Frakcijski protok fluida kojime se istiskivalo naftu prikazan je na slici 4-13 gdje se može vidjeti usporedan prikaz simulacijskih vrijednosti sa laboratorijskim.



Slika 4-13 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (25x25x25 Corey-Brooks)


4.4. Model broj 4 (1D)

Posljednji model koji se inicijaliziralo, model broj 4, geometrijski je jednodimenzionalan (slika 4-14). Postavljena je 1D mreža ćelija koja se sastojala od 50 ćelija u smjeru osi X i 1 ćelije u smjeru osi Y i Z (50x1x1).



Slika 4-14 Trodimenzionalni prikaz geometrije modela broj 4 (50x1x1) (t=1 min)

Naime, u literaturi numerička analiza heterogenosti protjecanja često se svodi na promatranje raspodjela zasićenja u vremenu i samo po duljini uzorka (tj. u smjeru osi X). Ovakva geometrija postavljena je sa pretpostavkom da bi opis protoka fluida kroz takvu jezgru trebao biti najviše linearan, s obzirom na to da se odvija pretežito u jednom smjeru. Na takav način, opet bi se praktično moglo uspoređivati s prijašnjim modelima, ali ponajprije dobiti bolje razumijevanje za postupak usklađivanja proizvodnje. Naime, ovakvim tipom modela koji je geometrijski jednostavan, najlakše se da "manipulirati", pa samim time i uviđati bitne zakonitosti. Analogija usklađivanja proizvodnih podataka istovjetna je kao i za prethodne modele inicijalizirane koristeći Corey-Brooks korelaciju, a krivulje relativnih propusnosti za model broj 4 (slika 4-16) također su se sastojale od različitih vrijednosti u odnosu na prošle modele kako bi se uspješno uskladilo podatke. Rezultat proizvodnje simulacijskog modela u odnosu na laboratorijsko mjerenje može se vidjeti na slici 4-15.




Slika 4-15 Usporedni prikaz proizvodnih krivulja laboratorijske analize i modela 4 (50x1x1)

Vrijednosti proizvodnih podataka kroz vremenske korake usporedno su prikazane tablicom 4-5, gdje se relativnom pogreškom odredilo točna odstupanja podataka mjerenih od simuliranih vrijednosti.

Tablica 4-5 Relativna pogreška odstupanja proizvodnih podataka simulacijskog modela broj 4 (1D) od laboratorijskog eksperimenta


Broj mjerjenja	Vrijeme t (h)	Vrijeme t (min)	Proizvedena nafta laboratorij V_o (cm ³)	Proizvedena nafta simulacijski V_o (cm ³)	Relativna pogreška (%)
0	0	0	0	0	0
1	0,040	2,37	2,62	1,611	-39
2	0,053	3,2	3,07	2,252	-27
3	0,073	4,35	3,42	3,192	-7
4	0,096	5,73	3,73	3,602	-3
5	0,121	7,28	4	3,962	-1
6	0,149	8,96	4,22	4,284	2
7	0,200	12	4,57	4,656	2
8	0,282	16,92	4,97	4,957	0
9	0,442	26,5	5,4	5,254	-3
10	0,696	41,75	5,74	5,620	-2
11	1,110	66,6	6,01	5,990	0
12	1,465	87,87	6,21	6,214	0
13	1,792	107,5	6,32	6,360	1

Krivulje relativnih propusnosti korištene za četvrti model prikazane su na slici 4-16.




Slika 4-16 Krivulje relativnih propusnosti prilagođene prema Corey-Brooks korelaciji za model broj 4 (1D)

Frakcijski protok fluida kojime se istiskivalo naftu prikazan je na slici 4-17 gdje se može vidjeti usporedan prikaz simulacijskih vrijednosti sa laboratorijskim.




Slika 4-17 Frakcijski protok vode tijekom zavodnjavanja jezgre u laboratoriju i simulacijskom modelu (1D)

Konačno, usporednim prikazom svih testiranih modela (slika 4-18) može se zaključiti da su svi simulacijski modeli, inicijalizirani uz korelirane vrijednosti relativnih propusnosti, reprezentativno opisivali laboratorijski eksperiment istiskivanja nafte vodom kroz jezgru stijene (engl. *fluid displacement*). Svaka testirana geometrija uspješno je sprovedena različitim krivuljama relativnih propusnosti, a modeli svaki za sebe u međusobnom odnosu imaju određene prednosti i mane, koje su malenih fluktuacija pa se mogu i zanemariti.




Slika 4-18 Međusobno usporedni prikaz proizvodnih krivulja laboratorijske analize i svih testiranih modela

Krivulje relativnih propusnosti prema Corey-Brooks korelaciji kojima su se uspješno uskladili rezultati modelima 2, 3 i 4 usporedno su prikazane na slici 4-19, gdje se može vidjeti kako je za svaku geometriju navedenih modela koje su međusobno različite, potrebno primijeniti i različite krivulje relativnih propusnosti da bi se uvjetno rečeno ostvario isti rezultat, što je u principu i bila svrha istraživanja. Naime, uspostavljen je model laboratorijskog eksperimenta istiskivanja nafte vodom u kojemu se izmjenom samo podataka o relativnoj propusnosti protoci mijenjaju a rezultat je sličan, čime bi se sada praktično moglo usklađivati i nova mjerenja izvođena u laboratoriju.



Slika 4-19 Usporedan prikaz krivulja relativnih propusnosti prema Corey-Brooks korelaciji korištenih za usklađivanje rezultata modelima 2, 3 i 4

Za svaki od analiziranih modela korištena je krivulja kapilarnog tlaka prikazana na slici 4-20.



Slika 4-20 Krivulja kapilarnog tlaka korištena tijekom ispitivanja

Dakle kapilarni tlak u ovome ispitivanju nije zanemaren s obzirom na to da kapilarne sile predstavljaju bitan faktor kad se radi o protoku fluida kroz ležište. Štoviše, ova tvrdnja potvrđena je testiranjem protoka kroz simulacijski model bez kapilarnih sila u odnosu za slučaj kada su one prisutne, čime se pokazalo da utječu na protok fluida. Simulacijski model osjetljiv je na male promjene ulaznih parametara, a uvođenjem kapilarnih sila zamijećena je i neznatna promjena inicijalnog zasićenja fluida u stijeni što se pretpostavlja da je posljedica kapilarnog "end efekta". Zaključno po pitanju obzervacija može se utvrditi da je na manjim i modelima precizno aproksimiranim dimenzijama, fizikalni sustav ležišne stijene izrazito dinamičan.

5. ZAKLJUČAK

Prema prikazanim rezultatima, model koji se može prihvatiti za dalju upotrebu u praksi je model broj 3 (25x25x25).

Laboratorijske krivulje relativnih propusnosti nisu idealne za ležišnu simulaciju prije nego što ih se testira i prilagodi simulacijskim modelom jezgre stijene, pošto dolazi do promjene propusnosti na ulaznom dijelu jezgre, dok je to mjerenjem na izlazu nemoguće detektirati.

Simulacijski model jezgre (engl. *coreflood model*) osjetljiv je i na najmanje promjene ulaznih parametara, što je posljedica malih dimenzija ćelija.

Istraživanje vezano za simulacijski mikro-model nastavljeno je u smjeru inicijalizacije modela koji će simulirati eksperimente mješovitog istiskivanja nafte (s) plinom i vode (s) plinom, kako bi se razvio potpuniji set modela primjenjiv za tercijarne metode iskorištavanja ležišta ugljikovodika (EOR) i skladištenje CO₂. Za bolje testiranje numeričkih postavki modela (veličina ćelija, geometrija modela, koraci simulacije itd.) potrebno je više laboratorijskih analiza kojima će se potvrditi rezultati.

Sami proračun relativne propusnosti, parametra bez kojeg je nemoguć praktički bilo koji proračun kojim se predviđaju rezerve ili buduća proizvodnja, baziran je na materijalnom uravnoteženju pornog volumena, proizvedenih fluida i utisnutih količina fluida. Analitički, takvo uravnoteženje se svodi na cijeli volumen uzorka stijene (jezgre). Simulacijski model jezgre opisuje suptilnije promjene u pojedinim dijelovima uzorka i usklađivanjem krivulje relativne propusnosti u simulacijskom modelu s proizvedenim i utisnutim količinama fluida jednoznačno se potvrđuje da tako određena krivulja relativne propusnosti daje realne rezultate proizvodnje, za razliku od analitičkog proračuna koji rezultira s određenim odstupanjem, čime je i potvrđena hipoteza ovog rada.

Preporuke za dalje istraživanje su usklađivanje krivulja relativnih propusnosti mjerenih metodom ustaljenog protoka (engl. *steady state*). Takvi podatci nisu obrađeni u ovom radu, prije svega jer su analize nedostupne, a sama činjenica da se takve analize rjeđe izvode radi dugotrajnosti postupka potvrđuje potrebu za istraživanje simulacijskih načina interpretacije istih mjerenja izvedenih nekim modificiranim (i vremenski kraćim) postupkom.

6. LITERATURA

1. Darcy, H., 1856. *Les Fontaines Publiques de la Ville de Dijon (The Public Fountains of the City of Dijon)*. Paris: Dalmont.
2. Pettersen, Ø., 2006. Basics of Reservoir Simulation With the Eclipse Reservoir Simulator. Lecture Notes. University of Bergen, Norway.
3. Reddy, J. N., 1984. *An Introduction to The Finite Element Method* (Vol. 1). New York: McGraw-Hill Financial, Inc.
4. Schlumberger, 2014. *ECLIPSE Reference Manual*. Paris, Houston & The Hague: Schlumberger.
5. Schlumberger, 2014. *ECLIPSE Technical Description*. Paris, Houston & The Hague: Schlumberger.
6. Vulin, D., 2016. Višefazni protok u poroznoj stijeni. Skripta za kolegij Višefazni protok u poroznoj stijeni. Sveučilište u Zagrebu: Rudarsko-geološko-naftni fakultet.

internet izvori:

Brooks-Corey and related models: Relative permeability models - PetroWiki. 2016. [ONLINE] dostupno na: http://petrowiki.org/Relative_permeability_models#Brooks-Corey_and_related_models. [14 Srpanj 2016].

IZJAVA

Izjavljujem da sam ovaj diplomski rad samostalno izradio pod mentorstvom izv. prof. dr. sc. Domagoja Vulina.

Filip Kos